

chi2 \TeX

Полуавтоматический перевод рукописи книги
из формата chiwriter в формат L \TeX

Божевольнов Юстислав
кафедра математики физического факультета МГУ

МОСКВА САНКТ-ПЕТЕРБУРГ 2008

Ключевые слова

Распознавание математических формул, chiwriter, LaTeX

Аннотация

Современным стандартом верстки текстов научно-технического содержания является издательская система \LaTeX . Этот стандарт имеет ряд достоинств, среди них: признание научным сообществом и авторитетными издательствами, высокое качество получаемого результата, поддержка множества языков и относительная простота верстки¹. Самые популярные реализации MiK \TeX ² (windows), TeXlive³ (linux), MacTeX⁴ (MacOS) распространяются бесплатно. Формат документов \TeX является *макро-форматом*: для математических формул используется набор специальных текстовых команд, охватывающих (за редким исключением) весь спектр принятых в математике структур.

Тем не менее множество рукописей по различным причинам набраны в других форматах. В частности автор столкнулся с задачей по *переводу рукописи из формата программы ChiWriter*, поддержка которой прекращена в 1996 году. Содержание рукописи (книга по физической дисциплине) не оставил выбора в конечном формате преобразования — \TeX . Основная трудность заключалась в том, что не удалось найти сколько-нибудь подходящее средство для автоматической трансляции. Задача усложнялась отсутствием описания исходного формата.

Был произведен анализ формата документов ChiWriter. В результате “археологических раскопок” удалось получить графическую визуализацию текста, после чего стало ясно задача близка в широком смысле к задаче распознавания образов. Поскольку математические формулы весьма чувствительны к ошибкам в написании, главным стал вопрос о безошибочном разборе математических нотаций. После статистических исследований стало ясно, что “*простые*” структуры можно разбирать автоматически, но все же незначительное количество “*сложных*” мест требует ручного подхода. В такой постановке задачу удалось решить достаточно эффективно.

¹ Википедия использует именно этот макро-формат для математических формул http://en.wikipedia.org/wiki/Help:Displaying_a_formula

² <http://miktex.org/>

³ <http://www.tug.org/texlive/>

⁴ <http://www.tug.org/mactex/>

Краткий отчет

Исходный формат

chiwriter 3.14, WYSIWYG, прекращена поддержка в 1996 году
<http://en.wikipedia.org/wiki/ChiWriter>

Конечный формат

ЛАTeX, формат де-факто для текстов научно-технического содержания, макро-формат
<http://en.wikipedia.org/wiki/LaTeX>

Постановка задачи

- Анализ текста и, прежде всего, математических формул на возможность автоматического распознавания.
- Выработка четкого критерия для выбора
 - либо автоматического,
 - либо ручного режима распознавания.
- Безошибочное распознавание математических формул, пригодных для автоматического режима.

Этапы работы

- *Анализ формата данных (разметка текста, шрифты)* chiwriter 3.14 (реализованы классы для визуализации данных, Delphi)
- *Анализ структуры данных (текст с формулами)* (реализован программный комплекс для всевозможных статистических исследований структуры данных, Delphi)
- *Формулировка критерия выбора режима распознавания для базового элемента* (на основе проведенного статистического анализа, выработан критерий, “отсеивающий” 2% элементов для ручного распознавания)
- *Автоматический режим распознавания* (реализован конечный автомат для преобразования “псевдографических” данных в макро-формат системы ЛАTeX, Delphi)

- Ручное распознавание и сведение результатов (Delphi, Perl)
- Приведение полученного текста к стандартам верстки в системе L^AT_EX (учет стилистических особенностей верстки на русском языке, учет особенностей набора в системе L^AT_EX, Perl, Perl Regular Expressions)

Статистика

Базовым элементом для преобразования взята строка в формате chi

Всего строк: около 11 000

Всего строк для разбора в ручном режиме: около 200 (2%)

Объем получившейся рукописи: около 250 страниц А4

Результат

Рукопись в формате L^AT_EX передана научному редактору.

Иллюстрации

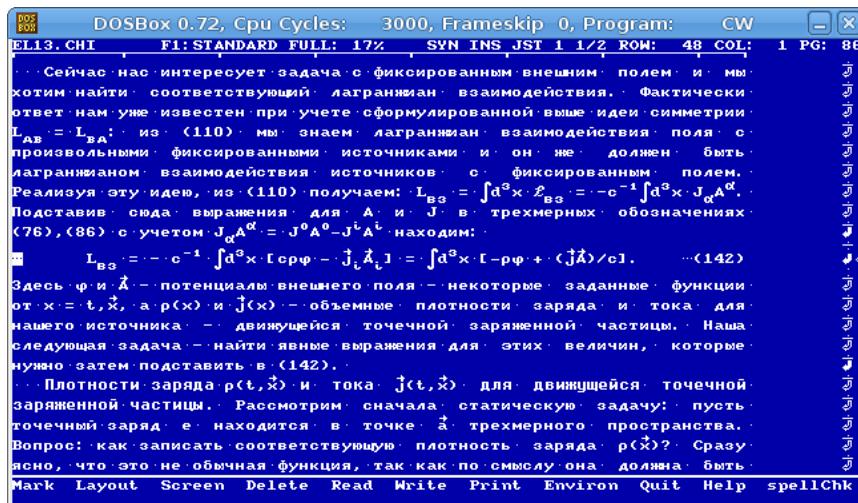


Рис. 1: Окно программы chiwriter. Если бы удалось найти матричный принтер, то примерно так бы выглядел печатный текст.

```

\+
kfuhyf;bfyjv \ dpfbvjltqcndbz \ bcnjxybrjd \ \ c \ \ abrcbhjdfyysv \ \ gjktv&
\-
\+
\+          \oi \23      -1\oi \23      \7a
\5Htfkbpez 'ne blt.^ bp \1(110) \5gjkexftv\1: L\ \ = \d\ x \#L\ \ \1= \5- \1c\ \ \ d\ x J\ A\ \5&
\-
dp \0j \5dp \0j \7a
\+
\5Gjlcnfdbd \ c.lf \ dshf;tybz \ lkz \ \1A \ \5b \ \1J \ \5d \ nht[vthys[ \ j,jpyfxtbybz[
\-
\+
\+          \7a \20 0 i i
\1(76),(86) \5c extnjv \1J\ A\ = J\ A\ -J\ A\ \5yf[jlbv\1: \,
\-
\7a
\+
\+          \2-1 \oi \23 \9L L \oi \23 \9LL
\^ \ \ \ \ \ \1L\ \ = \5- \1c\ \ \ d\ x [c\7rv \1- j\ A\ ] = \ d\ x [-\7rv \1+ (jA)/c].\ \ \ \ \ ^\1(142)\,
\-
\5dp \0j \2i i \0j
\-
\+          \9L
\5Pltcm \7v \5b \1A \5- gjntywbfks dytiytuj gjkz - ytrjnjhst \ pflfyyst \ aeyrwbb
\-
\+
\+          \9L L
\5jn \1x = t,x\5- f \7r\1(x) \5b \1j(x) \5- j,Jtvyst \ gkjnyjcnb \ pfhzlf \ b \ njrf \ lkz
\-

```

Рис. 2: “Внутренности” формата chiwriter. На примере этого фрагмента можно проследить дальнейшие метаморфозы.

Реализуя эту идею, из (110) получаем: $L_{вз} = \frac{\Gamma_3}{J} \times \mathbf{E}_{вз} = -c \frac{\Gamma_3}{J} \mathbf{d} \times \mathbf{J}_{вз}$.

Подставив сюда выражения для \mathbf{A} и \mathbf{J} в трехмерных обозначениях (76), (86) с учетом $\mathbf{J} = \frac{\alpha}{\alpha} \mathbf{A} - \mathbf{J}_{вз}$ находим:

$$L_{вз} = -c \frac{\Gamma_3}{J} \mathbf{d} \times [\alpha \mathbf{r}\varphi - J_{вз}] = \frac{\Gamma_3}{J} \mathbf{d} \times [-\mathbf{r}\varphi + (J_{вз})/\alpha]. \quad (142)$$

Здесь φ и \mathbf{A} – потенциалы внешнего поля – некоторые заданные функции от $\mathbf{x} = t, \mathbf{r}$, а $p(\mathbf{x})$ и $\mathbf{j}(\mathbf{x})$ – объемные плотности заряда и тока для нашего источника – движущейся точечной заряженной частицы. Наша следующая задача – найти явные выражения для этих величин, которые нужно затем подставить в (142).

Плотности заряда $p(t, \mathbf{r})$ и тока $\mathbf{j}(t, \mathbf{r})$ для движущейся точечной

Рис. 3: Возможно ли машинное распознавание? Этот вопрос потребовал более наглядного представления информации, чем на предыдущем рисунке. Для удобства исследования “на глаз” для каждого типа символов используется свой цвет.

Реализуя эту идею, из (110) получаем:

```
$L_{\text{вз}}
= \int d^3x \times \mathcal{L}_{\text{вз}}
= -c^{-1} \int d^3x \times J_{\alpha} A^{\alpha}.
```

Подставив сюда выражения для A и J в трехмерных обозначениях (76), (86) с учетом $J_{\alpha} A^{\alpha} = J^0 A^0 - J^i A^i$ находим:

```
%%
\begin{equation*}\label{142}
L_{\text{вз}}
= -c^{-1} \int d^3x [c\rho \varphi - \vec{v}_j \cdot \vec{A}] \\
= \int d^3x [-\rho \varphi + (\vec{v}_j \cdot \vec{A})/c].
\end{equation*}%%

```

Здесь φ и \vec{A} --- потенциалы внешнего поля --- некоторые заданные функции от $x = t, \vec{x}$, а $\rho(x)$ и $\vec{j}(x)$ --- объемные плотности заряда и тока для нашего источника --- движущейся точечной заряженной частицы. Наша

Рис. 4: Фрагмент в формате L^AT_EX получен в автоматическом режиме.

Сейчас нас интересует задача с фиксированным внешним полем и мы хотим найти соответствующий лагранжиан взаимодействия. Фактически ответ нам уже известен при учете сформулированной выше идеи симметрии $L_{AB} = L_{BA}$: из (110) мы знаем лагранжиан взаимодействия поля с произвольными фиксированными источниками и он же должен быть лагранжианом взаимодействия источников с фиксированным полем. Реализуя эту идею, из (110) получаем: $L_{\text{вз}} = \int d^3x \mathcal{L}_{\text{вз}} = -c^{-1} \int d^3x J_{\alpha} A^{\alpha}$. Подставив сюда выражения для A и J в трехмерных обозначениях (76), (86) с учетом $J_{\alpha} A^{\alpha} = J^0 A^0 - J^i A^i$ находим:

$$L_{\text{вз}} = -c^{-1} \int d^3x [c\rho\varphi - \vec{j} \cdot \vec{A}] = \int d^3x [-\rho\varphi + (\vec{j} \cdot \vec{A})/c]. \quad (142)$$

Здесь φ и \vec{A} --- потенциалы внешнего поля --- некоторые заданные функции от $x = t, \vec{x}$, а $\rho(x)$ и $\vec{j}(x)$ --- объемные плотности заряда и тока для нашего источника --- движущейся точечной заряженной частицы. Наша следующая задача --- найти явные выражения для этих величин, которые нужно затем подставить в (142).

Плотности заряда $\rho(t, \vec{x})$ и тока $\vec{j}(t, \vec{x})$ для движущейся точечной заряженной частицы. Рассмотрим сначала статическую задачу:

Рис. 5: Типографские каноны (печатный вариант), L^AT_EX

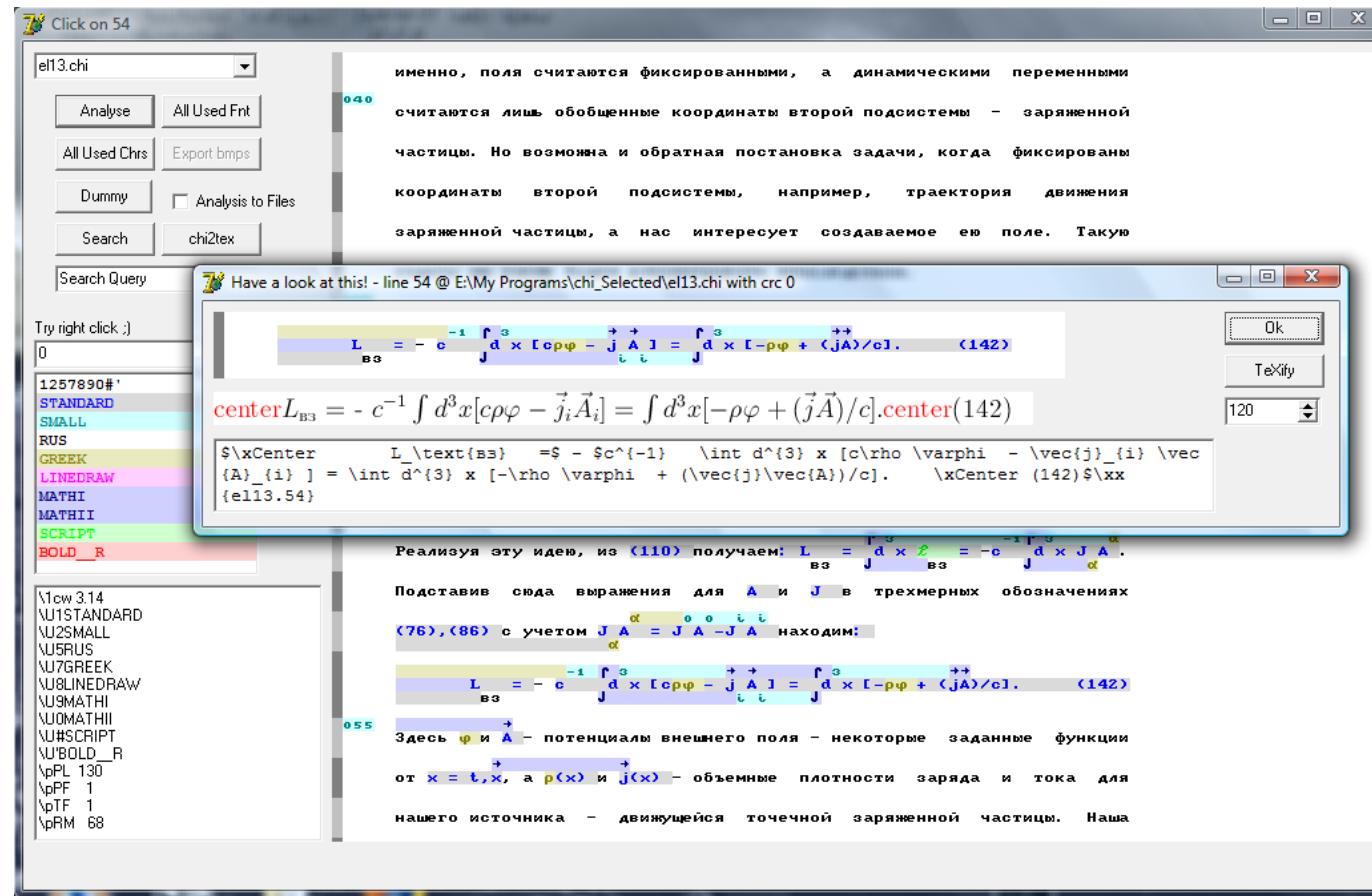


Рис. 6: Автоматический разбор строки.

The screenshot shows a software interface titled "E:\My Programs\chi_Selected\". On the left is a tree view of files and folders, with several items checked. In the center, there is a preview area showing four equations labeled 1, P, T, and PT, each with a condition and a note "(45)". To the right of the preview are several buttons: "Textify" (set to 120), "x-Emerge" (set to 0), "equation" (selected), and "aligned eqn". Below the preview area is a large text box containing the LaTeX code for the equations, starting with \begin{aligned} and ending with \end{aligned} and \tag{45}.

Рис. 7: Слишком громоздкие конструкции пришлось “обработать напильником” в ручном режиме.



Рис. 8: Кусочек таблицы символов chiwriter. Видно, что некоторые из их составные.